



PATENT APPLICATION

IN THE UNITED STATES PATENT AND TRADEMARK OFFICE

In re application of

Docket No: Q80581

Sadato AKAHORI

Appln. No.: 10/806,476

Group Art Unit: Unknown

Confirmation No.: 1699

Examiner: Unknown

Filed: March 23, 2004

For: APPARATUS AND PROGRAM FOR LEARNING DATA AND APPARATUS FOR
DECIDING MEANING OF IMAGE

SUBMISSION OF PRIORITY DOCUMENTS

Commissioner for Patents
P.O. Box 1450
Alexandria, VA 22313-1450

Sir:

Submitted herewith are two (2) certified copies of the priority documents on which
claims to priority was made under 35 U.S.C. § 119. The Examiner is respectfully requested to
acknowledge receipt of said priority documents.

Respectfully submitted,

SUGHRUE MION, PLLC
Telephone: (202) 293-7060
Facsimile: (202) 293-7860

WASHINGTON OFFICE

23373

CUSTOMER NUMBER

for
Jeffrey Schmitt
Darryl Mexic
Registration No. 23,063

#41,574

Enclosures: Japan 2003-079574
Japan 2004-072646

Date: August 6, 2004

BEST AVAILABLE COPY

日 本 国 特 許 庁
JAPAN PATENT OFFICE

Sagato AKAHOKI Q80581
APPARATUS AND PROGRAM FOR
LEARNING DATA AND APPARATUS.....
Filing Date: March 23, 2004
Application No. 10/806,476
Darryl Mexic 202-293-7060
1 of 2

別紙添付の書類に記載されている事項は下記の出願書類に記載されて
いる事項と同一であることを証明する。

This is to certify that the annexed is a true copy of the following application as filed
with this Office.

出 願 年 月 日 2 0 0 3 年 3 月 2 4 日
Date of Application:

出 願 番 号 特 願 2 0 0 3 - 0 7 9 5 7 4
Application Number:
[ST. 10/C]: [J P 2 0 0 3 - 0 7 9 5 7 4]


出 願 人 富士写真フイルム株式会社
Applicant(s):

CERTIFIED COPY OF
PRIORITY DOCUMENT

2 0 0 3 年 1 0 月 6 日

特許庁長官
Commissioner,
Japan Patent Office

今 井 康 夫



【書類名】 特許願

【整理番号】 P27495J

【あて先】 特許庁長官殿

【国際特許分類】 G06T 1/00

【発明者】

 【住所又は居所】 神奈川県足柄上郡開成町宮台 7 9 8 番地 富士写真フイルム株式会社内

 【氏名】 赤堀 貞登

【特許出願人】

 【識別番号】 000005201

 【氏名又は名称】 富士写真フイルム株式会社

【代理人】

 【識別番号】 100073184

 【弁理士】

 【氏名又は名称】 柳田 征史

【選任した代理人】

 【識別番号】 100090468

 【弁理士】

 【氏名又は名称】 佐久間 剛

【手数料の表示】

 【予納台帳番号】 008969

 【納付金額】 21,000円

【提出物件の目録】

 【物件名】 明細書 1

 【物件名】 図面 1

 【物件名】 要約書 1

 【包括委任状番号】 9814441

【プルーフの要否】 要

【書類名】 明細書

【発明の名称】 自己組織化マップを用いたデータ学習方法、装置およびプログラム、ならびに画像の意味判定方法、装置およびプログラム

【特許請求の範囲】

【請求項 1】 各々の対応クラスが分かっている複数の第 1 サンプル特徴ベクトルからなる第 1 学習データを学習することにより、参照特徴ベクトルのベクトル点の各々にクラスが対応付けられた暫定的な自己組織化マップを導出する第 1 学習工程と、

各々の対応クラスが分かっている複数の第 2 サンプル特徴ベクトルからなる第 2 学習データを学習することにより、前記暫定的な自己組織化マップに修正を加えて最終的な自己組織化マップを導出する第 2 学習工程を含み、

該第 2 学習工程が、

前記第 2 学習データ中の 1 つの第 2 サンプル特徴ベクトルを読み込み、前記暫定的な自己組織化マップ上において該 1 つの第 2 サンプル特徴ベクトルとの類似度が最も高い第 2 学習勝者ベクトルを特定する第 2 学習特定工程と、

該第 2 学習勝者ベクトルのベクトル点に対応付けられたクラスと、前記第 2 学習データが示す前記 1 つの第 2 サンプル特徴ベクトルの対応クラスとを比較し、該ベクトル点に対応付けられたクラスと該第 2 学習データが示す対応クラスが一致する場合には、該第 2 学習勝者ベクトルおよび前記暫定的な自己組織化マップ上において該第 2 学習勝者ベクトルの第 2 学習近傍に分布する複数の参照特徴ベクトルを、前記 1 つの第 2 サンプル特徴ベクトルとの類似度が増大するように修正し、一致しない場合には、該第 2 学習勝者ベクトルおよび該第 2 学習近傍に分布する複数の参照特徴ベクトルを、前記 1 つの第 2 サンプル特徴ベクトルとの類似度が減少するように修正する修正工程と、

前記複数の第 2 サンプル特徴ベクトルの全てについて、前記第 2 学習特定工程および前記修正工程を各々 1 回または複数回繰り返して、前記最終的な自己組織化マップを導出する工程を含むことを特徴とするデータ学習方法。

【請求項 2】 前記第 1 学習工程が、

ランダムな複数の参照特徴ベクトルが分布した初期自己組織化マップを提供す

る工程と、

各々が1つのクラスに対応し前記初期自己組織化マップと同じサイズを有する複数の頻度マップであって、各点に割り当てられた特定頻度値の初期値がゼロである複数の頻度マップを提供する工程と、

前記第1学習データ中の1つの第1サンプル特徴ベクトルを読み込み、前記初期自己組織化マップ上において該1つの第1サンプル特徴ベクトルとの類似度が最も高い第1学習勝者ベクトルを特定する第1学習特定工程と、

該第1学習勝者ベクトルおよび前記初期自己組織化マップ上において該第1学習勝者ベクトルの第1学習近傍に分布する複数の参照特徴ベクトルを、前記1つの第1サンプル特徴ベクトルとの類似度が增大するように修正するとともに、前記第1学習データが示す前記1つの第1サンプル特徴ベクトルの対応クラスに対応する頻度マップ上の、該第1学習勝者ベクトルおよび該第1学習近傍に分布する複数の参照特徴ベクトルの各ベクトル点に対応する点において、前記特定頻度値を増分させる更新工程と、

前記複数の第1サンプル特徴ベクトルの全てについて、前記第1学習特定工程および前記更新工程を各々1回または複数回繰り返して前記暫定的な自己組織化マップを導出する工程と、

前記複数の頻度マップに基づいて、各ベクトル点における出現確率が最も高いクラスを、該ベクトル点に対応付けられる前記クラスとする工程を含むことを特徴とする請求項1記載のデータ学習方法。

【請求項3】 前記複数の第1サンプル特徴ベクトルおよび前記複数の第2サンプル特徴ベクトルの各々が、画像の特徴を示す特徴量を成分とするベクトルであって、前記第1学習データおよび前記第2学習データが示す前記対応クラスの各々が、画像の意味を示すクラスであることを特徴とする請求項1または2記載のデータ学習方法。

【請求項4】 請求項3記載のデータ学習方法による学習後の前記最終的な自己組織化マップを用いて対象画像の意味を判定する方法であって、

前記対象画像から特徴ベクトルを抽出する工程と、

前記最終的な自己組織化マップ上において該特徴ベクトルとの類似度が最も高

い勝者ベクトルを特定する工程と、

前記最終的な自己組織化マップにおいて該勝者ベクトルのベクトル点に対応付けられたクラスが示す意味を、前記対象画像の意味とする工程を含むことを特徴とする方法。

【請求項 5】 請求項 3 記載のデータ学習方法による学習後の前記最終的な自己組織化マップを用いて対象画像の意味を判定する装置であって、

前記対象画像から特徴ベクトルを抽出する手段と、

前記最終的な自己組織化マップ上において該特徴ベクトルとの類似度が最も高い勝者ベクトルを特定する手段と、

前記最終的な自己組織化マップにおいて該勝者ベクトルのベクトル点に対応付けられたクラスが示す意味を、前記対象画像の意味とする手段を備えていることを特徴とする装置。

【請求項 6】 請求項 3 記載のデータ学習方法による学習後の前記最終的な自己組織化マップを用いて対象画像の意味を判定するためのプログラムであって、コンピュータを、

前記対象画像から特徴ベクトルを抽出する手段、

前記最終的な自己組織化マップ上において該特徴ベクトルとの類似度が最も高い勝者ベクトルを特定する手段、および

前記最終的な自己組織化マップにおいて該勝者ベクトルのベクトル点に対応付けられたクラスが示す意味を、前記対象画像の意味とする手段として機能させるためのプログラム。

【請求項 7】 各々の対応クラスが分かっている複数の第 1 サンプル特徴ベクトルからなる第 1 学習データを学習することにより、参照特徴ベクトルのベクトル点の各々にクラスが対応付けられた暫定的な自己組織化マップを導出する第 1 学習手段と、

各々の対応クラスが分かっている複数の第 2 サンプル特徴ベクトルからなる第 2 学習データを学習することにより、前記暫定的な自己組織化マップに修正を加えて最終的な自己組織化マップを導出する第 2 学習手段を備え、

該第 2 学習手段が、

前記第2学習データ中の1つの第2サンプル特徴ベクトルを読み込み、前記暫定的な自己組織化マップ上において該1つの第2サンプル特徴ベクトルとの類似度が最も高い第2学習勝者ベクトルを特定する第2学習特定手段と、

該第2学習勝者ベクトルのベクトル点に対応付けられたクラスと、前記第2学習データが示す前記1つの第2サンプル特徴ベクトルの対応クラスとを比較し、該ベクトル点に対応付けられたクラスと該第2学習データが示す対応クラスが一致する場合には、該第2学習勝者ベクトルおよび前記暫定的な自己組織化マップ上において該第2学習勝者ベクトルの第2学習近傍に分布する複数の参照特徴ベクトルを、前記1つの第2サンプル特徴ベクトルとの類似度が増大するように修正し、一致しない場合には、該第2学習勝者ベクトルおよび該第2学習近傍に分布する複数の参照特徴ベクトルを、前記1つの第2サンプル特徴ベクトルとの類似度が減少するように修正する修正手段と、

前記複数の第2サンプル特徴ベクトルの全てについて、前記第2学習特定手段および前記修正手段を各々1回または複数回繰返し動作させ、前記最終的な自己組織化マップを導出する手段を備えていることを特徴とするデータ学習装置。

【請求項8】 コンピュータを、

各々の対応クラスが分かっている複数の第1サンプル特徴ベクトルからなる第1学習データを学習することにより、参照特徴ベクトルのベクトル点の各々にクラスが対応付けられた暫定的な自己組織化マップを導出する第1学習手段、および

各々の対応クラスが分かっている複数の第2サンプル特徴ベクトルからなる第2学習データを学習することにより、前記暫定的な自己組織化マップに修正を加えて最終的な自己組織化マップを導出する第2学習手段であって、

前記第2学習データ中の1つの第2サンプル特徴ベクトルを読み込み、前記暫定的な自己組織化マップ上において該1つの第2サンプル特徴ベクトルとの類似度が最も高い第2学習勝者ベクトルを特定する第2学習特定手段と、

該第2学習勝者ベクトルのベクトル点に対応付けられたクラスと、前記第2学習データが示す前記1つの第2サンプル特徴ベクトルの対応クラスとを比較し、該ベクトル点に対応付けられたクラスと該第2学習データが示す対応クラスが一

致する場合には、該第2学習勝者ベクトルおよび前記暫定的な自己組織化マップ上において該第2学習勝者ベクトルの第2学習近傍に分布する複数の参照特徴ベクトルを、前記1つの第2サンプル特徴ベクトルとの類似度が增大するように修正し、一致しない場合には、該第2学習勝者ベクトルおよび該第2学習近傍に分布する複数の参照特徴ベクトルを、前記1つの第2サンプル特徴ベクトルとの類似度が減少するように修正する修正手段と、

前記複数の第2サンプル特徴ベクトルの全てについて、前記第2学習特定手段および前記修正手段を各々1回または複数回繰返し動作させ、前記最終的な自己組織化マップを導出する手段を備えた第2学習手段として動作させるためのデータ学習プログラム。

【発明の詳細な説明】

【0001】

【発明の属する技術分野】

本発明は、データ学習方法、装置およびプログラムに関し、特に、画像の意味判定等の情報の内容判定処理に使用する自己組織化マップを導出するための、教師あり学習によるデータ学習方法、装置およびプログラムに関する。本発明はまた、かかるデータ学習方法による学習により得られた自己組織化マップを用いて画像の意味を判定する方法、装置およびプログラムにも関する。

【0002】

【従来の技術】

情報のクラス分類や検索等の手法として、従来からのクラスタリング法等に代わるものとして、近年、自己組織化マップを利用した手法が用いられ始めている。

【0003】

自己組織化マップとは、複数の多次元ベクトルが空間的に配されたマップであり、各多次元ベクトルは、1つの参照データの特徴を示す複数のパラメータを成分とするベクトル（以下、「参照特徴ベクトル」と呼ぶ）である。この自己組織化マップ上では、予め多数のサンプルデータを学習することにより、互いに類似する参照特徴ベクトルが互いに近い位置に配置されるように構成されている。

【0 0 0 4】

この学習の工程は、一般的には「教師なし学習」であり、まずランダムな複数の参照特徴ベクトルが分布した初期自己組織化マップを用意した後、学習対象の特徴ベクトルを読み込み、該特徴ベクトルとの類似度が最も高い勝者ベクトルを自己組織化マップ上の参照特徴ベクトルから見つけ出し、該勝者ベクトルおよびその近傍に分布する参照特徴ベクトルを該学習対象の特徴ベクトルとの類似度が增大するように修正する各工程を繰り返すことによって学習を行う。かかる教師なし学習後の自己組織化マップを用いれば、複数の入力情報について、その各々の特徴を示すベクトルと最も類似度の高い勝者ベクトルを自己組織化マップ上から探索し、該入力情報を自己組織化マップ上のその勝者ベクトルの位置に写像することにより、情報を2次元マップ状に一覧表示すること等が可能となる（たとえば、特許文献1および2参照）。このような一覧表示では、類似の特徴を有する情報（たとえば類似の画像や類似の商品情報等）が互いに近くに配置され表示されることになるので、視覚的に捉え易く、一覧性がよい。また、教師なし学習後の自己組織化マップにおいて特に類似の傾向が強いベクトルが集まった複数の島状の領域をクラスターとして定め、入力情報の特徴を示すベクトルと最も類似度の高い勝者ベクトルがいずれのクラスターに属するかを調べることにより、入力情報の分類や優先順位付けを行う手法も提案されている（たとえば、特許文献3および4参照）。

【0 0 0 5】

情報の分類や一覧表示の用途には上記のような教師なし学習による自己組織化マップを用いれば足りるが、情報の内容判定処理（クラス判定処理）に応用するには、学習後の自己組織化マップ上の各ベクトル点と情報の内容（クラス）とが互いに関連付けられている必要がある。そこで、予めクラス分けされいずれのクラスに属するかが分かっているデータを学習させる「教師あり学習」と自己組織化マップを組み合わせた「修正対向伝搬ネットワーク（Modified Counter Propagation; MCP）」という手法等も提案されている（たとえば、非特許文献1参照）。この修正対向伝搬ネットワークの手法における学習工程では、自己組織化マップと同じ大きさの「頻度マップ」がクラスごとに

用意され、自己組織化マップの学習と並行して、各クラスごとに、自己組織化マップ上の各ベクトル点にそのクラスに属する学習対象の特徴ベクトルに対する勝者ベクトルが現れる頻度を示す、頻度マップの作成が行われる。これにより、学習終了後には、互いに類似する参照特徴ベクトルが互いに近い位置に配置された自己組織化マップと、自己組織化マップ上の各ベクトル点において最も出現確率が高いクラス情報を示した対応クラスのマップとが得られることとなる。したがって、かかる学習後の自己組織化マップを用いれば、入力情報の特徴を示すベクトルと最も類似度の高い勝者ベクトルを自己組織化マップ上から探索し、対応クラスのマップ上における該勝者ベクトルのベクトル点の対応点を参照することにより、入力情報がいずれのクラスに属する情報であるのかを判定することが可能となる。

【0006】

一方、情報のクラス分類や検索等の処理ならびに情報の内容判定処理に用いることのできる別の手法として、やはり教師あり学習である学習ベクトル量子化 (Learning Vector Quantization; LVQ) と呼ばれる学習手法による学習結果を用いる手法も提案されている (たとえば、非特許文献1および2参照)。この学習ベクトル量子化による学習手法では、対応クラスが分かっている複数の参照特徴ベクトルからなる参照特徴ベクトル群を予め用意した後、やはり対応クラスが分かっている学習対象の特徴ベクトルを順次読み込み、該学習対象の特徴ベクトルとの類似度が最も高い勝者ベクトルを参照特徴ベクトル群から見つけ出し、該勝者ベクトルに対応付けられている対応クラスと該学習対象の特徴ベクトルに対応付けられている対応クラスとが一致する場合には、該勝者ベクトルを該学習対象の特徴ベクトルとの類似度が増大するように修正し、一致しない場合には、該勝者ベクトルを該学習対象の特徴ベクトルとの類似度が減少するように修正する各工程を繰り返すことによって学習を行う。かかる学習後の参照特徴ベクトル群を用いれば、入力情報の特徴を示すベクトルと最も類似度の高い勝者ベクトルを該参照特徴ベクトル群の中から見つけ出し、その勝者ベクトルに対応付けられているクラスを参照することにより、入力情報がいずれのクラスに属する情報であるのかを判定することが可能となる。この学習ベ

クトル量子化は、特徴ベクトルを用いた教師あり学習によるデータ学習手法である点で、上記の修正対向伝搬ネットワークによる自己組織化マップを用いた学習手法と類似するが、参照特徴ベクトル群の学習に空間的相互作用がない点で、自己組織化マップを用いた学習手法と異なる。すなわち、上述のとおり、自己組織化マップを用いた学習手法では、参照特徴ベクトル群は概念上自己組織化マップ上に空間的に配され、勝者ベクトルのみならず該勝者ベクトルの近傍に分布する参照特徴ベクトルにも学習の効果が及ぶが、学習ベクトル量子化による手法では、かかる参照特徴ベクトル群の空間的配置および近傍学習は行われない。

【0 0 0 7】**【特許文献 1】**

特開 2 0 0 2 - 4 1 5 4 5 号公報

【0 0 0 8】**【特許文献 2】**

特開 2 0 0 1 - 3 3 7 9 5 3 号公報

【0 0 0 9】**【特許文献 3】**

特開 2 0 0 1 - 3 0 6 6 1 2 号公報

【0 0 1 0】**【特許文献 4】**

特開 2 0 0 1 - 2 8 3 1 8 4 号公報

【0 0 1 1】**【非特許文献 1】**

徳高他、「自己組織化マップの応用－多次元情報の 2 次元可視化」、
海文堂、1 9 9 9 年、p. 1 - 1 9、6 3 - 7 5

【0 0 1 2】**【非特許文献 2】**

谷萩他、「ニューラルネットワークとファジイ信号処理」、コロナ社
、1 9 9 8 年、p. 4 1 - 4 7

【0 0 1 3】

【発明が解決しようとする課題】

上記のとおり、各ベクトル点と情報の内容（クラス）が関連付けられた学習後の自己組織化マップを用いれば情報の内容判定処理を行うことができ、かかる自己組織化マップを導出するためのデータ学習手法として修正対向伝搬ネットワークによる手法が提案されている。しかしながら、この手法による学習後の自己組織化マップを用いた情報の内容判定処理では、特に勝者ベクトルとして特定された参照特徴ベクトルがクラス間の境界付近の参照特徴ベクトルである場合において、誤判定が起りやすい。たとえば、クラス A、B および C のいずれかに属することが分かっている多数の特徴ベクトルを修正対向伝搬ネットワークの手法により学習した結果、図 1 3 に模式的に示すような自己組織化マップおよび対応クラスのマップが得られたとする。学習後の自己組織化マップ上では、前述のように互いに類似する参照特徴ベクトルが互いに近い位置に配置されるようになっている。しかしながら、各クラスに対応する領域内における参照特徴ベクトル同士の類似度は、各領域の中央付近では特に高いが、クラス間の境界付近では低くなる傾向がある。したがって、たとえば、内容（クラス）判定処理の対象である入力情報の特徴を表すベクトルに対する勝者ベクトルが、図 1 3 に示すベクトル V_1 のようなクラス B に対応する領域の中央付近の参照特徴ベクトルである場合は、「入力情報のクラスは B である」という判定結果の信頼性は比較的高いが、勝者ベクトルがベクトル V_2 のようなクラス間の境界付近の参照特徴ベクトルである場合には判定結果の信頼性が低く、内容判定処理の精度が制限される。たとえば、意味が分かっている画像の特徴を示す特徴ベクトルを学習して画像の意味判定処理を行う場合には、このことは、画像の意味特定精度の低下を意味する。その他にも、修正対向伝搬ネットワークによる学習手法では、自己組織化マップが収束する前の段階、すなわちマップ上の参照特徴ベクトルがまだランダムな状態である初期の学習段階における学習内容が最終的な自己組織化マップに反映されることも、その後の内容判定処理の精度を低くする要因となり、特に学習サンプル数が少ない場合等には精度低下の傾向が大きくなる。

【0 0 1 4】

一方、情報の内容判定処理に適用可能な別の学習手法である学習ベクトル量子

化の手法では、上記のとおり、各クラスごとに適当数の初期の参照特徴ベクトルを選定して参照特徴ベクトル群を予め用意する必要があるが、この初期の参照特徴ベクトルの成分値ならびに各クラスごとの「適当数」をどのように定めるかは、学習ベクトル量子化では特に重要である。これは、学習ベクトル量子化では、自己組織化マップを用いた学習手法と異なり近傍学習の概念が取り入れられておらず、各参照特徴ベクトルは各々独立に学習を行う（すなわち、独立に修正されていく）ため、初期に定めた各クラスごとの参照特徴ベクトルの「適当数」は学習を行っても固定されたままであり、また初期の成分値の定め方によっては学習を全くまたはほとんど行わない参照特徴ベクトルも生じ得るからである。しかしながら、この初期の参照特徴ベクトルの成分値ならびに各クラスごとの「適当数」を好適に定めることは實際上容易でなく、学習ベクトル量子化による学習結果を用いた内容判定処理の精度を制限する要因となっている。

【0015】

本発明は、かかる事情に鑑み、自己組織化マップによるデータ学習方法、装置およびプログラムにおいて、より高い精度で画像の意味判定等の情報の内容判定処理を行うことができる自己組織化マップの導出を可能にすること、ならびに、かかる学習後の自己組織化マップを用いて、より高い精度で、情報の内容判定処理の一形態である画像の意味判定処理を行うことを目的とするものである。

【0016】

【課題を解決するための手段】

すなわち、本発明に係るデータ学習方法は、各々の対応クラスが分かっている複数の第1サンプル特徴ベクトルからなる第1学習データを学習することにより、参照特徴ベクトルのベクトル点の各々にクラスが対応付けられた暫定的な自己組織化マップを導出する第1学習工程と、各々の対応クラスが分かっている複数の第2サンプル特徴ベクトルからなる第2学習データを学習することにより、上記の暫定的な自己組織化マップに修正を加えて最終的な自己組織化マップを導出する第2学習工程を含み、該第2学習工程が、上記の第2学習データ中の1つの第2サンプル特徴ベクトルを読み込み、暫定的な自己組織化マップ上において該1つの第2サンプル特徴ベクトルとの類似度が最も高い第2学習勝者ベクトルを

特定する第2学習特定工程と、該第2学習勝者ベクトルのベクトル点に対応付けられたクラスと、上記の第2学習データが示す当該1つの第2サンプル特徴ベクトルの対応クラスとを比較し、該ベクトル点に対応付けられたクラスと該第2学習データが示す対応クラスが一致する場合には、該第2学習勝者ベクトルおよび暫定的な自己組織化マップ上において該第2学習勝者ベクトルの第2学習近傍に分布する複数の参照特徴ベクトルを、当該1つの第2サンプル特徴ベクトルとの類似度が増大するように修正し、一致しない場合には、該第2学習勝者ベクトルおよび該第2学習近傍に分布する複数の参照特徴ベクトルを、当該1つの第2サンプル特徴ベクトルとの類似度が減少するように修正する修正工程と、上記の複数の第2サンプル特徴ベクトルの全てについて、上記の第2学習特定工程および修正工程を各々1回または複数回繰り返して、最終的な自己組織化マップを導出する工程を含むことを特徴とするデータ学習方法である。

【0017】

ここで、上記の第1学習工程は、修正対向伝搬ネットワークの手法によるものでもよい。すなわち、上記の第1学習工程は、ランダムな複数の参照特徴ベクトルが分布した初期自己組織化マップを提供する工程と、各々が1つのクラスに対応し上記の初期自己組織化マップと同じサイズを有する複数の頻度マップであって、各点に割り当てられた特定頻度値の初期値がゼロである複数の頻度マップを提供する工程と、上記の第1学習データ中の1つの第1サンプル特徴ベクトルを読み込み、上記の初期自己組織化マップ上において該1つの第1サンプル特徴ベクトルとの類似度が最も高い第1学習勝者ベクトルを特定する第1学習特定工程と、該第1学習勝者ベクトルおよび上記の初期自己組織化マップ上において該第1学習勝者ベクトルの第1学習近傍に分布する複数の参照特徴ベクトルを、当該1つの第1サンプル特徴ベクトルとの類似度が増大するように修正するとともに、上記の第1学習データが示す当該1つの第1サンプル特徴ベクトルの対応クラスに対応する頻度マップ上の、該第1学習勝者ベクトルおよび該第1学習近傍に分布する複数の参照特徴ベクトルの各ベクトル点に対応する点において、上記の特定頻度値を増分させる更新工程と、上記の複数の第1サンプル特徴ベクトルの全てについて、上記の第1学習特定工程および更新工程を各々1回または複数回

繰り返して上記の暫定的な自己組織化マップを導出する工程と、上記の複数の頻度マップに基づいて、各ベクトル点における出現確率が最も高いクラスを、該ベクトル点に対応付けられるクラスとする工程を含むものであってもよい。

【0018】

また、本発明に係るデータ学習装置は、各々の対応クラスが分かっている複数の第1サンプル特徴ベクトルからなる第1学習データを学習することにより、参照特徴ベクトルのベクトル点の各々にクラスが対応付けられた暫定的な自己組織化マップを導出する第1学習手段と、各々の対応クラスが分かっている複数の第2サンプル特徴ベクトルからなる第2学習データを学習することにより、上記の暫定的な自己組織化マップに修正を加えて最終的な自己組織化マップを導出する第2学習手段を備え、該第2学習手段が、上記の第2学習データ中の1つの第2サンプル特徴ベクトルを読み込み、暫定的な自己組織化マップ上において該1つの第2サンプル特徴ベクトルとの類似度が最も高い第2学習勝者ベクトルを特定する第2学習特定手段と、該第2学習勝者ベクトルのベクトル点に対応付けられたクラスと、上記の第2学習データが示す当該1つの第2サンプル特徴ベクトルの対応クラスとを比較し、該ベクトル点に対応付けられたクラスと該第2学習データが示す対応クラスが一致する場合には、該第2学習勝者ベクトルおよび暫定的な自己組織化マップ上において該第2学習勝者ベクトルの第2学習近傍に分布する複数の参照特徴ベクトルを、当該1つの第2サンプル特徴ベクトルとの類似度が増大するように修正し、一致しない場合には、該第2学習勝者ベクトルおよび該第2学習近傍に分布する複数の参照特徴ベクトルを、当該1つの第2サンプル特徴ベクトルとの類似度が減少するように修正する修正手段と、上記の複数の第2サンプル特徴ベクトルの全てについて、上記の第2学習特定手段および修正手段を各々1回または複数回繰返し動作させ、最終的な自己組織化マップを導出する手段を備えていることを特徴とするデータ学習装置である。

【0019】

また、本発明に係るデータ学習プログラムは、コンピュータを、各々の対応クラスが分かっている複数の第1サンプル特徴ベクトルからなる第1学習データを学習することにより、参照特徴ベクトルのベクトル点の各々にクラスが対応付け

られた暫定的な自己組織化マップを導出する第1学習手段、および、各々の対応クラスが分かっている複数の第2サンプル特徴ベクトルからなる第2学習データを学習することにより、上記の暫定的な自己組織化マップに修正を加えて最終的な自己組織化マップを導出する第2学習手段であって、上記の第2学習データ中の1つの第2サンプル特徴ベクトルを読み込み、暫定的な自己組織化マップ上において該1つの第2サンプル特徴ベクトルとの類似度が最も高い第2学習勝者ベクトルを特定する第2学習特定手段と、該第2学習勝者ベクトルのベクトル点に対応付けられたクラスと、上記の第2学習データが示す当該1つの第2サンプル特徴ベクトルの対応クラスとを比較し、該ベクトル点に対応付けられたクラスと該第2学習データが示す対応クラスが一致する場合には、該第2学習勝者ベクトルおよび暫定的な自己組織化マップ上において該第2学習勝者ベクトルの第2学習近傍に分布する複数の参照特徴ベクトルを、当該1つの第2サンプル特徴ベクトルとの類似度が増大するように修正し、一致しない場合には、該第2学習勝者ベクトルおよび該第2学習近傍に分布する複数の参照特徴ベクトルを、当該1つの第2サンプル特徴ベクトルとの類似度が減少するように修正する修正手段と、上記の複数の第2サンプル特徴ベクトルの全てについて、上記の第2学習特定手段および修正手段を各々1回または複数回繰返し動作させ、最終的な自己組織化マップを導出する手段を備えた第2学習手段として動作させるためのデータ学習プログラムである。

【0020】

ここで、本発明において「特徴ベクトル」とは、あるデータの特徴を表す複数のパラメータ（以下、「特徴量」と呼ぶ）を成分とするベクトルを指すものとする。たとえば、学習対象が画像データである場合には、1つの特徴ベクトルの成分としての特徴量としては、1つの画像の色の特徴、輝度の特徴、奥行情報、該画像に含まれるエッジの特徴、該画像をなす各画素列／行に沿った輝度値等の変化パターンの相関関係の特徴等を示す特徴量が使用され得る。また、「参照特徴ベクトル」とは、自己組織化マップ上の各ベクトル点に分布する特徴ベクトルを、「サンプル特徴ベクトル」とは、学習サンプルとしての特徴ベクトルをそれぞれ指すものとする。さらに、区別のため必要な個所においては、第1学習工程ま

たは手段において使用されるサンプル特徴ベクトルを「第1サンプル特徴ベクトル」と、第2学習工程または手段において使用されるサンプル特徴ベクトルを「第2サンプル特徴ベクトル」とそれぞれ呼ぶものとする。

【0021】

また、本発明において「類似度」とは、特徴ベクトル同士の類似の度合いを示す指標を指し、たとえば2つの特徴ベクトル間の特徴ベクトル空間におけるユークリッド距離や内積等が使用され得る。なお、類似度が「高い」または「低い」とは、その類似度の値の大小そのものではなく、たとえば上記のユークリッド距離を類似度として採用した場合には、類似度（すなわちユークリッド距離）の値が小さい方が両ベクトルは類似しているので「類似度が高い」こととなる。

【0022】

さらに、本発明において「勝者ベクトル」とは、自己組織化マップ上に分布する参照特徴ベクトルのうち、学習対象としてのサンプル特徴ベクトルまたは学習後のクラス分類対象としての特徴ベクトルとの類似度が最も高い参照特徴ベクトルを指すものとする。なお、区別のため必要な個所においては、第1サンプル特徴ベクトルとの類似度が最も高い勝者ベクトルを「第1学習勝者ベクトル」、第2サンプル特徴ベクトルとの類似度が最も高い勝者ベクトルを「第2学習勝者ベクトル」とそれぞれ呼ぶものとする。

【0023】

また、本発明において「近傍」とは、自己組織化マップ上において学習の効果が及ぶ、第1学習勝者ベクトルまたは第2学習勝者ベクトルの近傍領域を指し、たとえば第1学習勝者ベクトルまたは第2学習勝者ベクトルを中心とする $n \times n$ （ n は3以上の奇数）の近傍領域や、略円形の近傍領域等が採用され得る。なお、区別のために用いる「第1学習近傍」とは、第1学習工程または手段において用いられる近傍を、「第2学習近傍」とは、第2学習工程または手段において用いられる近傍をそれぞれ指すものとする。第1学習近傍および第2学習近傍のいずれについても、学習全体を通じて同一サイズの近傍が用いられてもよいし、学習が進むに従って学習の効果が及ぶ近傍のサイズが小さくされていってもよい。

【0024】

また、本発明において、第1学習工程または手段における各頻度マップ上の特定頻度値の増分幅は、学習全体を通じて同一であってもよいし、学習が進むに従って増分幅を大きくしていてもよい。また、勝者ベクトルおよび第1学習近傍中の全ての参照特徴ベクトルの対応点に同一の増分幅を適用してもよいし、勝者ベクトルにより近いものほど大きな増分幅を適用してもよい。

【0025】

さらに、本発明においては、上記の複数の第1サンプル特徴ベクトルおよび複数の第2サンプル特徴ベクトルの各々が、画像の特徴を示す特徴量を成分とするベクトルであって、上記の第1学習データおよび第2学習データが示す対応クラスの各々が、画像の意味を示すクラスであってもよい。

【0026】

また、本発明に係る画像の意味判定方法は、上記の本発明に係るデータ学習方法による学習後の上記の最終的な自己組織化マップを用いて対象画像の意味を判定する方法であって、該対象画像から特徴ベクトルを抽出する工程と、上記の最終的な自己組織化マップ上において該特徴ベクトルとの類似度が最も高い勝者ベクトルを特定する工程と、上記の最終的な自己組織化マップにおいて該勝者ベクトルのベクトル点に対応付けられたクラスが示す意味を、当該対象画像の意味とする工程を含むことを特徴とする方法である。

【0027】

また、本発明に係る画像の意味判定装置は、上記の本発明に係るデータ学習方法による学習後の上記の最終的な自己組織化マップを用いて対象画像の意味を判定する装置であって、該対象画像から特徴ベクトルを抽出する手段と、上記の最終的な自己組織化マップ上において該特徴ベクトルとの類似度が最も高い勝者ベクトルを特定する手段と、上記の最終的な自己組織化マップにおいて該勝者ベクトルのベクトル点に対応付けられたクラスが示す意味を、当該対象画像の意味とする手段を備えていることを特徴とする装置である。

【0028】

また、本発明に係る画像の意味判定プログラムは、上記の本発明に係るデータ学習方法による学習後の上記の最終的な自己組織化マップを用いて対象画像の意

味を判定するためのプログラムであって、コンピュータを、該対象画像から特徴ベクトルを抽出する手段、上記の最終的な自己組織化マップ上において該特徴ベクトルとの類似度が最も高い勝者ベクトルを特定する手段、および上記の最終的な自己組織化マップにおいて該勝者ベクトルのベクトル点に対応付けられたクラスが示す意味を、当該対象画像の意味とする手段として機能させるためのプログラムである。

【0029】

ここで、本発明において、学習対象または意味判定対象としての「画像」は、撮影したデジタル写真画像や、動画の1フレームの、1枚分全体に相当する全体画像であってもよいし、かかる全体画像をいくつかの画像片に分割したブロック画像（たとえば、 1024×1280 画素の全体画像を 32×32 画素の大きさに分割したそれぞれのブロック画像）であってもよい。また、本発明において対象画像の「意味を判定する」とは、その対象画像が何を撮影した画像であるか、どのような分類に属するか等を判定することを指し、たとえば、ブロック画像について、「空」、「山」、「草原」等のいずれの対象が撮影されたブロックであるかを判定することや、全体画像について、「人物写真」、「建物の写真」、「海の風景写真」等のいずれであるかを判定することが含まれる。また、本発明による対象画像の意味を判定する方法、装置およびプログラムには、具体的な意味づけの結果を出力として得ることを目的とするもののほか、たとえば判定された意味または自己組織化マップ上における勝者ベクトルの位置に基づき画像の探索、抽出、分類等を行うことを目的とするものも含まれることとする。

【0030】

【発明の効果】

本発明に係るデータ学習方法、装置およびプログラムは、第1学習工程または手段により各ベクトル点にクラスが対応付けられた暫定的な自己組織化マップを導出し、その後、すでに相当程度収束した上記の暫定的な自己組織化マップを第2学習工程または手段における学習の初期状態として、学習ベクトル量子化を改良した手法を用いて暫定的な自己組織化マップをさらに修正して最終的な自己組織化マップを求めるものであるので、より高い精度で情報の内容判定処理を行う

ことができる最終的な自己組織化マップの導出が可能となる。また、通常の学習ベクトル量子化は各参照特徴ベクトルが各々独立に学習を行うものであるが、本発明の上記の第2学習工程または手段において使用される改良手法では近傍学習の概念が取り入れられているので、第1学習工程または手段により得られた暫定的な自己組織化マップ上に分布する参照特徴ベクトルの空間的相互関係、すなわち互いに類似する参照特徴ベクトルは互いに近い位置に配置されているという特性を壊すことなく、該暫定的な自己組織化マップに好適な修正を加え、後に続く内容判定処理の精度を向上させることができる。

【0031】

また、本発明に係る画像の意味判定方法、装置およびプログラムは、上記のような手法で導出された最終的な自己組織化マップを用いて対象画像の意味判定を行うものであるので、高い精度で正しい意味を判定することができる。

【0032】

【発明の実施の形態】

以下、図面により、本発明の例示的な実施形態を詳細に説明する。

【0033】

まず、図1から図10を用いて、本発明に係るデータ学習方法の1つの実施形態を説明する。この実施形態に係るデータ学習方法は、第1学習工程と第2学習工程からなるものであり、第1学習工程については図1から図7を、第2学習工程については図8から図10を用いて説明する。

【0034】

図1は、本実施形態に係るデータ学習方法の第1学習工程の手順を示したフローチャートである。この第1学習工程は、修正対向伝搬ネットワークの手法を用いたものである。

【0035】

まず、図1のステップ10において、乱数発生プログラムを用いる等して、図2の(a)に概念的に示すようなランダムな複数の参照特徴ベクトルが分布した初期自己組織化マップを用意する。ここで、本実施形態に係るデータ学習方法は、特に画像の意味判定処理に使用する自己組織化マップの導出を目的とするもの

であるとする。したがって使用される参照特徴ベクトルおよびサンプル特徴ベクトルは画像の特徴を示す特徴量を成分とするベクトルであり、サンプル特徴ベクトルに対応付けられているクラスは画像の意味を表すクラスである。具体的には、図2の(a)の初期自己組織化マップ上には、後述する10個の特徴量の値として適当な値を成分とする、10次元のランダムな参照特徴ベクトルが分布しているものとする。

【0036】

次に、ステップ12において、上記の初期自己組織化マップと同サイズであり、各点に特定頻度値の初期値としてゼロが割り当てられた頻度マップを、クラスごと、すなわち画像の意味ごとに用意する。画像の意味ごとに用意するとは、次のステップ14以降で学習する第1学習データ中に含まれる複数のサンプル特徴ベクトルの対応クラスが示す意味ごとに用意することを指す。ここで、実際に画像の意味判定処理に使用する自己組織化マップを導出するには多種多様な意味の画像を学習しなければならない場合が多いが、本実施形態では説明の便宜のため「空」、遠景としての「山」、および「草原」のいずれかの意味を有する画像のみを学習するものとし、したがって、ステップ12で用意する頻度マップも図2の(b)に示す3枚のみであるとする。

【0037】

このように学習の初期状態が用意された後、図1のステップ14から22からなる繰返し処理を行うことにより、第1学習データの学習が行われる。

【0038】

まず、ステップ14において、第1学習データ中の1つのサンプル特徴ベクトルが、学習対象として読み込まれる。本実施形態では、第1学習データ中の各サンプル特徴ベクトルは、「空」の画像、「山」の画像または「草原」の画像であることが分かっている 32×32 画素の小画像の特徴を示す10個の特徴量を成分とする10次元の特徴ベクトルであるとする。10個の特徴量としては、具体的には、YCC表色系で表されたその小画像の3つの成分値の、画素間平均値ならびに標準偏差、および当該小画像から導出された縦エッジ画像と横エッジ画像の成分値の、各々の絶対値の画素間平均値ならびに標準偏差を使用するものとする。

る。縦エッジ画像および横エッジ画像は、各小画像の Y C C 表色系における輝度成分の画像に対し、図 3 に示すようなエッジ検出用のフィルターを適用することにより求めることができる。第 1 学習データには、各サンプル特徴ベクトルの対応クラス、すなわち対応する意味の情報も含まれている。

【0039】

次に、図 1 のステップ 16 において、現在の初期自己組織化マップ上から、ステップ 14 で読み込まれた現在のサンプル特徴ベクトルとの類似度が最も高い参照特徴ベクトルが探索され、勝者ベクトルとして特定される。本実施形態では、類似度として特徴ベクトル空間におけるユークリッド距離を使用するものとし、したがってステップ 16 ではサンプル特徴ベクトルとの特徴ベクトル空間におけるユークリッド距離が最も小さい参照特徴ベクトルが、勝者ベクトルとして特定される。

【0040】

続いて、ステップ 18 において、ステップ 16 で特定された勝者ベクトル、および現在の初期自己組織化マップ上で該勝者ベクトルの近傍（第 1 学習近傍） 3×3 のベクトル点に分布する参照特徴ベクトルが、現在のサンプル特徴ベクトルとの類似度が增大するように、すなわち現在のサンプル特徴ベクトルとのユークリッド距離が小さくなるように修正される。次に、ステップ 20 において、第 1 学習サンプルが示す現在のサンプル特徴ベクトルの対応クラス（すなわち意味）に対応する頻度マップ上において、勝者ベクトルおよびその近傍 3×3 の対応点の特定頻度値が、+1 だけ増分される。その後、ステップ 22 において第 1 学習データ中に未学習のサンプル特徴ベクトルが残っているか否かが確認され、第 1 学習データ中の全てのサンプル特徴ベクトルを学習し終わるまで、ステップ 14 から 22 からの処理が繰り返される。

【0041】

ここまでの処理を、上記の繰り返し処理の第 1 回目、第 2 回目および第 3 回目における具体的な処理をそれぞれ概念的に示した、図 4、5 および 6 を用いてより詳細に説明する。

【0042】

まず、第1回目の繰返し処理のステップ14において読み込まれたサンプル特徴ベクトルが、第1学習データの示す対応クラスの意味が「空」であるベクトルであるとし、ステップ16において、図4(a)の左側の図に白抜きで示す参照特徴ベクトルが、勝者ベクトルとして特定されたとする。すると、図4(a)の右側の図に示すように、勝者ベクトルおよびその近傍 3×3 のベクトル点に分布する参照特徴ベクトルが、図示のサンプル特徴ベクトルとのユークリッド距離が小さくなるように修正される。さらに、第1学習データが示す現在のサンプル特徴ベクトルに対応する意味は「空」であるので、図4(b)に示すように、「空」の頻度マップ上において、勝者ベクトルおよびその近傍 3×3 の対応点の特定頻度値が、+1だけ増分される。「山」および「草原」の頻度マップに対しては、ここでは処理は加えられない。

【0043】

次に、第2回目の繰返し処理のステップ14において読み込まれたサンプル特徴ベクトルが、第1学習データの示す対応クラスの意味が「山」であるベクトルであるとし、ステップ16において、図5(a)の左側の図に白抜きで示す参照特徴ベクトルが、勝者ベクトルとして特定されたとする。すると、図5(a)の右側の図に示すように、勝者ベクトルおよびその近傍 3×3 のベクトル点に分布する参照特徴ベクトルが、図示のサンプル特徴ベクトルとのユークリッド距離が小さくなるように修正される。さらに、第1学習データが示す現在のサンプル特徴ベクトルに対応する意味は「山」であるので、図5(b)に示すように、「山」の頻度マップ上において、勝者ベクトルおよびその近傍 3×3 の対応点の特定頻度値が、+1だけ増分される。

【0044】

続いて、第3回目の繰返し処理のステップ14において読み込まれたサンプル特徴ベクトルが、第1学習データの示す対応クラスの意味が「空」であるベクトルであるとし、ステップ16において、図6(a)の左側の図に白抜きで示す参照特徴ベクトルが、勝者ベクトルとして特定されたとする。すると、図6(a)の右側の図に示すように、勝者ベクトルおよびその近傍 3×3 のベクトル点に分布する参照特徴ベクトルが、図示のサンプル特徴ベクトルとのユークリッド距離

が小さくなるように修正される。さらに、第1学習データが示す現在のサンプル特徴ベクトルに対応する意味は「空」であるので、図6（b）に示すように、「空」の頻度マップ上において、勝者ベクトルおよびその近傍 3×3 の対応点の特定頻度値が、+1だけ増分される。

【0045】

かかる繰返し処理による学習が進んでくると、初期自己組織化マップは次第に収束し、類似の特徴を示す参照特徴ベクトルが、徐々に互いに近い位置に集まってくる。一方、それぞれの頻度マップ上でも、徐々に島状の頻度の分布が形成されていく。

【0046】

第1学習データ中の全てのサンプル特徴ベクトルの学習が終了すると、図1の処理はステップ24へ進み、M回の学習が終了したかが確認される。Mは、第1学習データ全体の繰返し学習回数の設定値であり、1以上のいかなる回数であってもよい。Mとして2以上の回数を設定し、第1学習データを複数回繰返し学習することにより、より適切に収束した暫定的な自己組織化マップを求めることができる。

【0047】

M回の学習が終了すると、図1に示した処理はステップ26へと進み、当該終了時点での初期自己組織化マップが、第1学習工程による暫定的な自己組織化マップとされる。図7の（a）は、この暫定的な自己組織化マップを概念的に示したものである。

【0048】

さらに、ステップ28において、各頻度マップに基づいて、各ベクトル点において出現確率が最も高いクラスを、そのベクトル点に対応付ける。具体的には、学習終了後の各頻度マップを規格化して重ね合わせ、各点において最も高い規格化特定頻度値を示しているクラスすなわち意味をその点に割り当てた、図7の（b）に示すような意味のマップを作成し、図7の（a）に示す暫定的な自己組織化マップの各ベクトル点に、この意味のマップ上における対応点に割り当てられた意味を対応付ける等の処理により、ステップ28の対応付けを行うことができ

る。なお、各ベクトル点において「出現確率が最も高いクラス」をそのベクトル点に対応付けるとしたが、各頻度マップの規格化を行わずに、単に最も高い特定頻度値を示しているクラスを各ベクトル点に対応付けるような形態も、本発明の範囲に属するものとする。

【0049】

なお、上記の本実施形態における第1学習工程では、学習全体を通じて 3×3 の一定サイズの近傍（第1学習近傍）を使用した。学習の初期段階においては 7×7 等の大きな近傍を使用し、学習が進むに従って近傍のサイズを小さくしていてもよい。また、近傍の形状も、矩形に限られない。

【0050】

さらに、上記の本実施形態における第1学習工程では、各頻度マップ上の特定頻度値の増分幅は、学習全体を通じて+1で一定であったが、学習が進むに従って増分幅を大きくしていてもよい。また、勝者ベクトルおよび第1学習近傍中の全ての参照特徴ベクトルの対応点に同一の増分幅を適用する形態に限られず、たとえばガウス分布状の増分幅を採用し、勝者ベクトルの対応点により近い点ほど増分幅が大きくなるようにしてもよい。

【0051】

続いて、図8から図10を用いて、本実施形態の第2学習工程について説明する。図8は、本実施形態に係るデータ学習方法の第2学習工程の手順を示したフローチャートである。この第2学習工程は、上記に説明した第1学習工程により導出された、各ベクトル点に意味が対応付けられた（概念的に言えば図7の（b））に示す意味のマップが対応付けられた図7の（a）に示す暫定的な自己組織化マップを、学習の初期状態として用いて行うものである。

【0052】

まず、ステップ30において、第2学習データ中の1つのサンプル特徴ベクトルが、学習対象として読み込まれる。この第2学習データは、上記の第1学習データと同一のデータを再度用いるものであってもよいし、第1学習データ中の各第1サンプル特徴ベクトルと同様の10個の特徴量を成分とし、各々が「空」、「山」または「草原」の小画像の特徴を表した第2サンプル特徴ベクトルからな

るデータであれば、第1学習データと異なるものであってもよい。第2学習データには、各第2サンプル特徴ベクトルの対応クラス、すなわち対応する意味の情報も含まれている。

【0053】

次に、ステップ32において、第1学習工程により得られた暫定的な自己組織化マップ上から、ステップ30で読み込まれた現在のサンプル特徴ベクトルとの類似度が最も高い参照特徴ベクトル、すなわち現在のサンプル特徴ベクトルとの特徴ベクトル空間におけるユークリッド距離が最も小さい参照特徴ベクトルが探索され、勝者ベクトルとして特定される。

【0054】

続いて、ステップ34において、第2学習データが示す現在のサンプル特徴ベクトルの対応クラスすなわち意味と、暫定的な自己組織化マップにおいてステップ32で特定された勝者ベクトルに対応付けられたクラスすなわち意味が、一致するか否かが確認される。その結果、一致する場合には、ステップ36において、暫定的な自己組織化マップ上の勝者ベクトルおよびその近傍3×3のベクトル点に分布する参照特徴ベクトルが、現在のサンプル特徴ベクトルとの類似度が増大するように、すなわち現在のサンプル特徴ベクトルとのユークリッド距離が小さくなるように修正される。一方、一致しない場合には、ステップ36'において、暫定的な自己組織化マップ上の勝者ベクトルおよびその近傍3×3のベクトル点に分布する参照特徴ベクトルが、現在のサンプル特徴ベクトルとの類似度が減少するように、すなわち現在のサンプル特徴ベクトルとのユークリッド距離が大きくなるように修正される。その後、ステップ38において第2学習データ中に未学習のサンプル特徴ベクトルが残っているか否かが確認され、第2学習データ中の全てのサンプル特徴ベクトルを学習し終わるまで、ステップ30から38からなる処理が繰り返される。

【0055】

この繰り返し処理において実際に行われる処理の内容を、図9および図10の概念図を用いてより具体的に説明する。

【0056】

図9の概念図では、ある回の繰返し処理におけるステップ30で読み込まれたサンプル特徴ベクトルが、第2学習データの示す対応クラスの意味が「草原」であるベクトルであるとし、ステップ32において、図9の(a)に白抜きで示す暫定的な自己組織化マップ上の参照特徴ベクトルが、勝者ベクトルとして特定されたとする。そこで、ステップ34における確認のため、図7の(b)に示すものと同一の図9の(b)に示す意味のマップ上の勝者ベクトルの対応点を参照すると、勝者ベクトルに対応付けられた意味は「草原」であり、上記の第2学習データが示す意味と一致することが分かる。そのため、図8の処理はステップ36に進み、勝者ベクトルおよび図9の(a)に破線で示す3×3の近傍(第2学習近傍)内に分布する参照特徴ベクトルが、現在のサンプル特徴ベクトルとのユークリッド距離が小さくなるように修正される。図9の(b)に示す意味のマップに対しては、修正等の処理は施されない。

【0057】

一方、図10の概念図では、別の回の繰返し処理におけるステップ30で読み込まれたサンプル特徴ベクトルが、第2学習データの示す対応クラスの意味が「草原」であるベクトルであり、ステップ32において、図10の(a)に白抜きで示す暫定的な自己組織化マップ上の参照特徴ベクトルが、勝者ベクトルとして特定されたとする。ステップ34における確認のため、やはり図7の(b)に示すものと同一の図10の(b)に示す意味のマップ上の、勝者ベクトルの対応点を参照すると、勝者ベクトルに対応付けられた意味は「山」であり、第2学習データが示す意味「草原」とは一致しないことが分かる。かかる不一致は、特にクラス間の境界付近の参照特徴ベクトルが勝者ベクトルとして特定されたときに生じやすい。意味が一致しないため、図8の処理はステップ36'に進み、勝者ベクトルおよび図10の(a)に破線で示す3×3の近傍(第2学習近傍)内に分布する参照特徴ベクトルが、現在のサンプル特徴ベクトルとのユークリッド距離が大きくなるように修正される。意味のマップに対しては、修正等の処理は施されない。

【0058】

このように、近傍学習の概念を取り入れた手法を用いて暫定的な自己組織化マ

ップを修正していくことにより、第1学習工程で得られた暫定的な自己組織化マップ上に分布する参照特徴ベクトルの空間的相互関係、すなわち互いに類似する参照特徴ベクトルは互いに近い位置に配置されているという特性を壊すことなく、好適な修正を行うことができる。これにより、後に続く情報の内容判定処理（本実施形態の場合は画像の意味判定処理）の精度を向上させることができる。

【0059】

繰返し処理による第2学習データ中の全てのサンプル特徴ベクトルの学習が終了すると、図8の処理はステップ40へ進み、N回の学習が終了したか否かが確認される。Nは第2学習データ全体の繰返し学習回数の設定数であり、1以上のいかなる回数であってもよい。

【0060】

N回の学習が終了すると、図8に示した処理はステップ42へと進み、当該終了時点での暫定的な自己組織化マップが、本実施形態のデータ学習方法による最終的な自己組織化マップとされる。この最終的な自己組織化マップの各ベクトル点には、図7の（b）に示す意味のマップの各対応点が示す意味が対応付けられている。

【0061】

なお、上記の本実施形態における第2学習工程では、学習全体を通じて 3×3 の一定サイズの近傍（第2学習近傍）を使用したのが、学習の初期段階においてはより大きな近傍を使用し、学習が進むに従って近傍のサイズを小さくしていてもよい。また、近傍の形状も、矩形に限られない。

【0062】

以上、本発明の1つの実施形態によるデータ学習方法について説明したが、本発明に係るデータ学習方法の第1学習工程は、上記した修正対向伝搬ネットワークの手法を利用したものに限られず、各ベクトル点にクラスが対応付けられ相当程度収束した暫定的な自己組織化マップが得られるものであれば、他のいかなる手法によるものでもよい。たとえば、上記した頻度のマップを作成せずに、楕円による近似等により各クラスがカバーするベクトル点の範囲を画定する手法等を用いてもよい。

【0063】

また、上記の実施形態においては特徴ベクトル空間における2つの特徴ベクトル間のユークリッド距離を類似度として用いたが、これに限られず、2つの特徴ベクトル間の内積等を用いてもよい。

【0064】

さらに、上記の実施形態は、画像の意味特定処理に使用する自己組織化マップの導出を目的とするものであり、したがって使用されるサンプル特徴ベクトルおよび参照特徴ベクトルは画像の特徴を表す特徴量を成分とするものであり、各クラス情報は画像の意味を示す情報であったが、これに限られず、本発明は、あらゆる情報の内容判定処理のための自己組織化マップ導出に適用可能であることは言うまでもない。また、同じように画像の意味特定処理に使用する自己組織化マップの導出を目的とする場合でも、サンプル特徴ベクトルおよび参照特徴ベクトルの成分として用いられ得る特徴量は、上記した10個の特徴量に限られないことも言うまでもない。

【0065】

また、上記の実施形態は、説明の便宜上、方法の実施形態として説明したが、以上の説明に基づいて実施することのできるデータ学習装置およびデータ学習プログラムも、本発明の範囲に属するものである。

【0066】

次に、図11および図12を用いて、本発明に係る画像の意味判定方法の1つの実施形態を説明する。

【0067】

図11は、ステップ56において本発明の1つの実施形態であるブロック画像の意味を判定する方法を利用した、全体画像に含まれる各画像領域の意味特定処理の全体的な手順を示したフローチャートである。この実施形態は、本発明に係るデータ学習方法の上記に説明した実施形態により導出された最終的な自己組織化マップを用いて、 32×32 画素からなる各ブロック画像の意味判定を行うものであり、図11の処理では、その判定結果に基づいて、全体画像に含まれる各画像領域の意味が特定される。ここで、「画像領域」とは、全体画像中において

「空」、「山」、「草原」等の撮影対象のいずれかに対応すると考えられる個々の有意な領域を指す。図 1 1 の処理は、その後、意味に基づく画像分類や、各意味に対応する画像領域ごとに区別された条件による画像処理を行うために有用な処理である。

【 0 0 6 8 】

まず、ステップ 5 0 において、全体画像を表す画像データが入力データとして読み込まれる。ここでは、全体画像は $1 0 2 4 \times 1 2 8 0$ 画素のデジタル写真画像であるとする。

【 0 0 6 9 】

次に、ステップ 5 2 において、全体画像に含まれる各画像領域が特定される。この特定は、たとえば、RGB 表色系で表された全体画像について、R、G および B の各成分の濃度値を、隣接画素間でそれぞれ比較して、いずれの濃度値の差もが所定の閾値を超える場合にそれらの画素を統合する処理を行い、かかる比較・統合処理を上記の所定の閾値によってはそれ以上の統合が起こらなくなるまで繰り返すこと等により行われる。また、このようにして得られた画像領域のうちノイズまたは無視し得る要素と考えられるような微小な画像領域を、隣接する画像領域にさらに統合する処理を行ってもよい。このさらなる統合は、たとえば、各微小な画像領域の各隣接画像領域のうち接する境界長が最も長い隣接画像領域に、その微小な画像領域を統合すること等により行われる。なお、以上は 1 つの例に過ぎず、ステップ 5 2 における画像領域の特定手法は、他のいかなる方法によるものでもよい。

【 0 0 7 0 】

続いて、ステップ 5 4 において、ステップ 5 0 で読み込まれた全体画像が、複数のブロック画像に分割される。ここでは、各ブロック画像は $3 2 \times 3 2$ 画素の画像である。なお、図 1 1 では、説明の便宜のため実際よりも粗い分割で示してある。

【 0 0 7 1 】

次に、ステップ 5 6 において、学習後の最終的な自己組織化マップを用いて各ブロック画像の意味が判定され、その結果に基づいて各画像領域の意味が特定さ

れる。ここで用いられる自己組織化マップは、本発明の上述した実施形態に係るデータ学習方法により導出された最終的な自己組織化マップである。ステップ56において行われる処理の詳細な手順を、以下、図12のフローチャートを用いて具体的に説明する。

【0072】

まず、図12のステップ60において、図11のステップ52で特定された複数の画像領域のうちの1つの画像領域に包含されるブロック画像が特定される。ここで、1つの画像領域に包含されるブロック画像とは、その画像領域に完全に包含されているブロック画像を言い、画像領域間の境界にまたがるブロック画像は含まないものとする。

【0073】

次に、ステップ62において、ステップ60で特定されたブロック画像の1つから、特徴ベクトルが抽出される。ここでは、抽出される特徴ベクトルは、意味判定に使用される自己組織化マップが学習したサンプル特徴ベクトルの成分と同様の特徴量、すなわち、YCC表色系で表された当該ブロック画像の3つの成分値の、画素間平均値ならびに標準偏差、および当該ブロック画像から導出された縦エッジ画像と横エッジ画像の成分値の、各々の絶対値の画素間平均値ならびに標準偏差の、10個の特徴量を成分とするベクトルである。

【0074】

続いて、ステップ64において、上述した実施形態に係るデータ学習方法により導出された最終的な自己組織化マップ上から、ステップ62で抽出した特徴ベクトルとの類似度が最も高い参照特徴ベクトルが探索され、勝者ベクトルとして特定される。ここでは、上述した実施形態に係るデータ学習方法において使用されたのと同様の特徴ベクトル空間におけるユークリッド距離が、特徴ベクトル間の類似度として使用され、したがって、ステップ62で抽出した特徴ベクトルとのユークリッド距離が最も小さい参照特徴ベクトルが、勝者ベクトルとして特定されている。

【0075】

次に、ステップ66において、ステップ64で特定された勝者ベクトルのベク

トル点に対応付けられた意味（図 7（b）の意味のマップ参照）が、現在のブロック画像の意味として割り当てられ、現在のブロック画像の意味判定が完了する。

【0076】

続いて、ステップ 68 において、現在の画像領域に含まれるブロック画像がまだ残っているか否かが確認され、現在の画像領域に含まれる全てのブロック画像の意味が判定されるまで、ステップ 62 から 68 が繰り返される。

【0077】

現在の画像領域に含まれる全てのブロック画像の意味の判定が終了すると、ステップ 70 において、各ブロック画像の判定された意味のうち最多のものが、現在の画像領域の意味として特定される。その後、ステップ 72 において、未処理の画像領域が残っているか否かが確認され、全ての画像領域の意味が特定されるまで、ステップ 60 からステップ 72 が繰り返される。このようにして、図 11 のステップ 56 の処理が完了すると、図示のように、各画像領域の意味「空」、「山」および「草原」が特定される。

【0078】

なお、上記の図 12 に示した処理は一例であって、たとえば、図 12 のステップ 64 の後に、特徴ベクトルと勝者ベクトルとのユークリッド距離が所定の閾値より大きい場合には、ステップ 66 に進まずに「意味判定不能」との判定をしてステップ 68 へと進むステップを設ける等、追加の工程が含まれていてもよい。

【0079】

また、上記の実施形態は全体画像を分割して得られた各ブロック画像の意味を判定するものであったが、本発明による画像の意味判定処理は、全体画像自体の意味判定処理にも適用可能であることは言うまでもない。この場合、使用される自己組織化マップは、たとえば、「人物写真」、「建物の写真」、「海の風景写真」等であることが分かっている全体画像を本発明によるデータ学習方法により予め学習して得られた最終的な自己組織化マップである。

【0080】

なお、上記の実施形態は、説明の便宜上、方法の実施形態として説明したが、

以上の説明に基づいて実施することのできる画像の意味判定装置および画像の意味判定プログラムも、本発明の範囲に属するものである。

【0081】

以上、本発明の実施形態について詳細に述べたが、これらの実施形態は例示的なものに過ぎず、本発明の技術的範囲は、本明細書中の特許請求の範囲のみによって定められるべきものであることは言うまでもない。

【図面の簡単な説明】

【図1】

本発明の1つの実施形態に係るデータ学習方法の第1学習工程の手順を示したフローチャート

【図2】

図1の第1学習工程における初期状態の初期自己組織化マップおよび頻度マップを示した概念図

【図3】

エッジ画像の導出に用いられるエッジ検出用フィルターの例を示した図

【図4】

図1の第1学習工程における第1回目の繰返し処理の例を示した概念図

【図5】

図1の第1学習工程における第2回目の繰返し処理の例を示した概念図

【図6】

図1の第1学習工程における第3回目の繰返し処理の例を示した概念図

【図7】

図1の第1学習工程によって得られる暫定的な自己組織化マップおよび意味のマップを示した概念図

【図8】

本発明の1つの実施形態に係るデータ学習方法の第2学習工程の手順を示したフローチャート

【図9】

図8の第2学習工程における1つの繰返し処理の例を示した概念図

【図 1 0】

図 8 の第 2 学習工程における別の繰返し処理の例を示した概念図

【図 1 1】

本発明の 1 つの実施形態に係るブロック画像の意味を判定する方法を利用した、全体画像に含まれる各画像領域の意味特定処理の手順を示したフローチャート

【図 1 2】

図 1 1 の意味特定処理における意味特定手法の詳細な手順を示したフローチャート

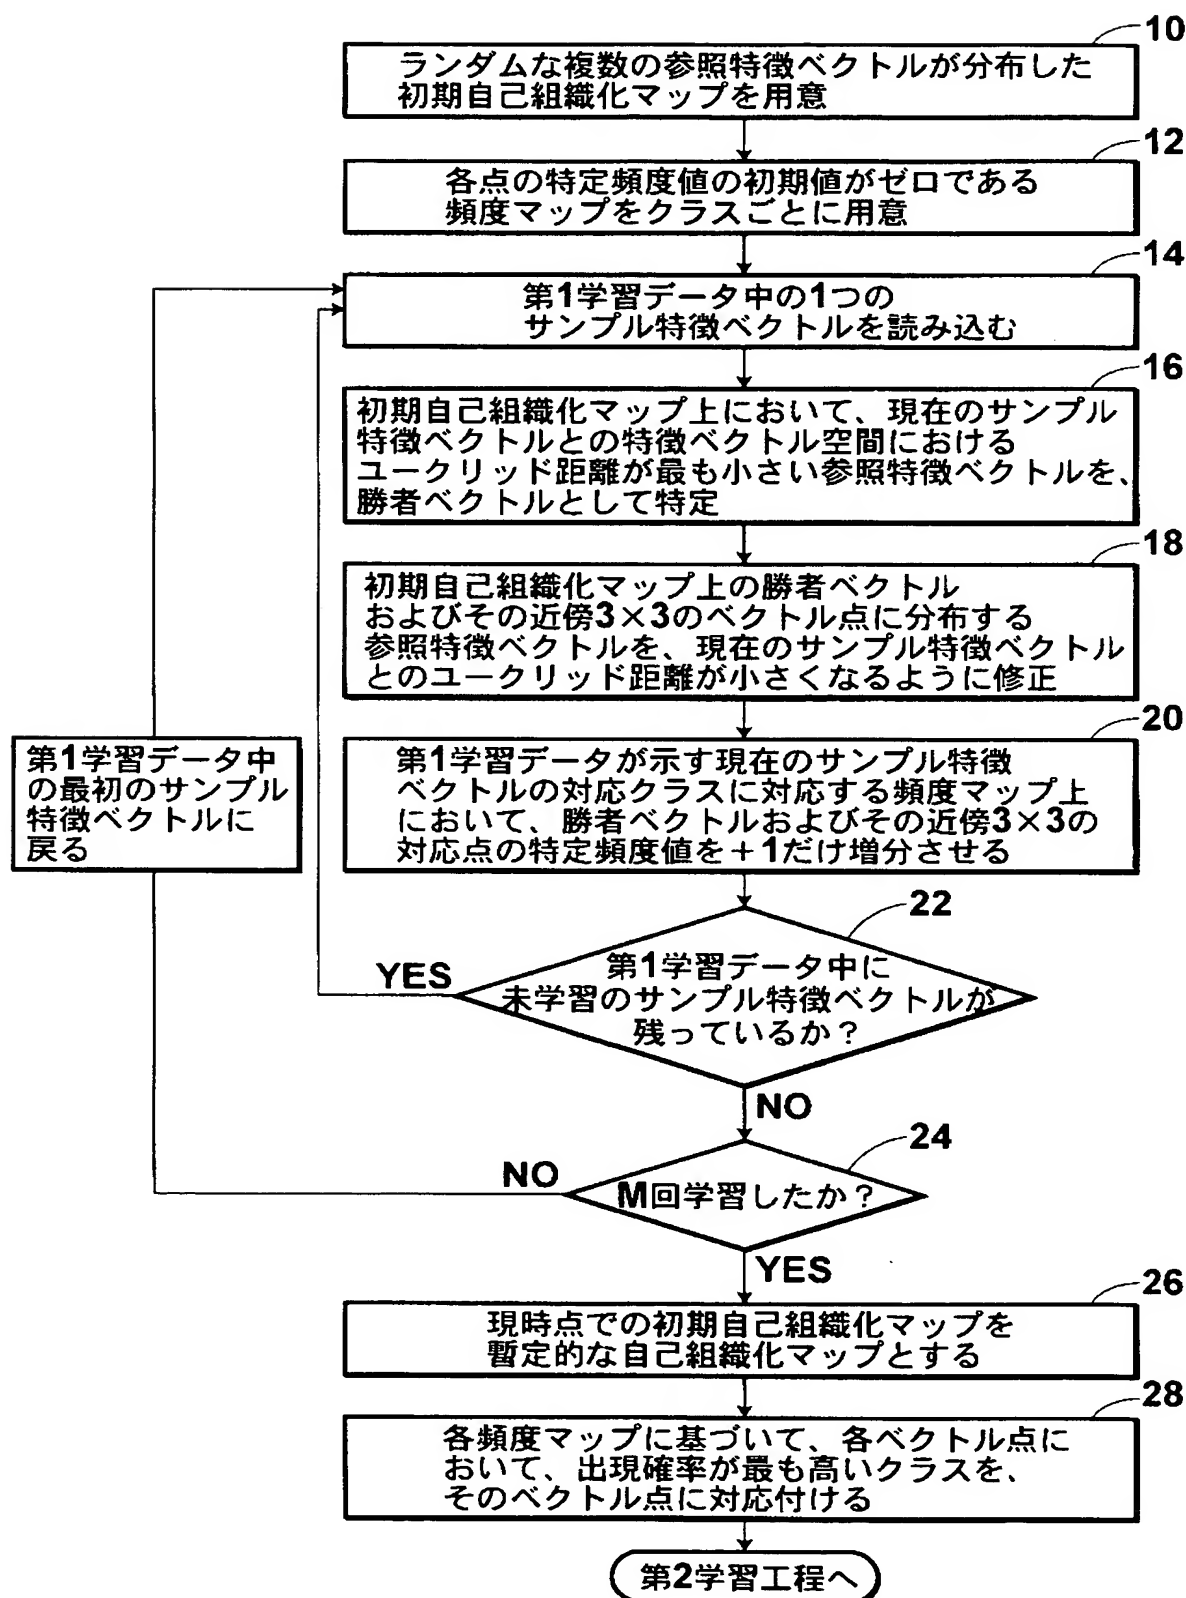
【図 1 3】

従来の修正対向伝搬ネットワークによるデータ学習手法によって得られる自己組織化マップおよび対応クラスのマップを示した概念図


【書類名】

図面


【図 1】




【図 2】




(a)



空



山



草原

(b)

【図 3】

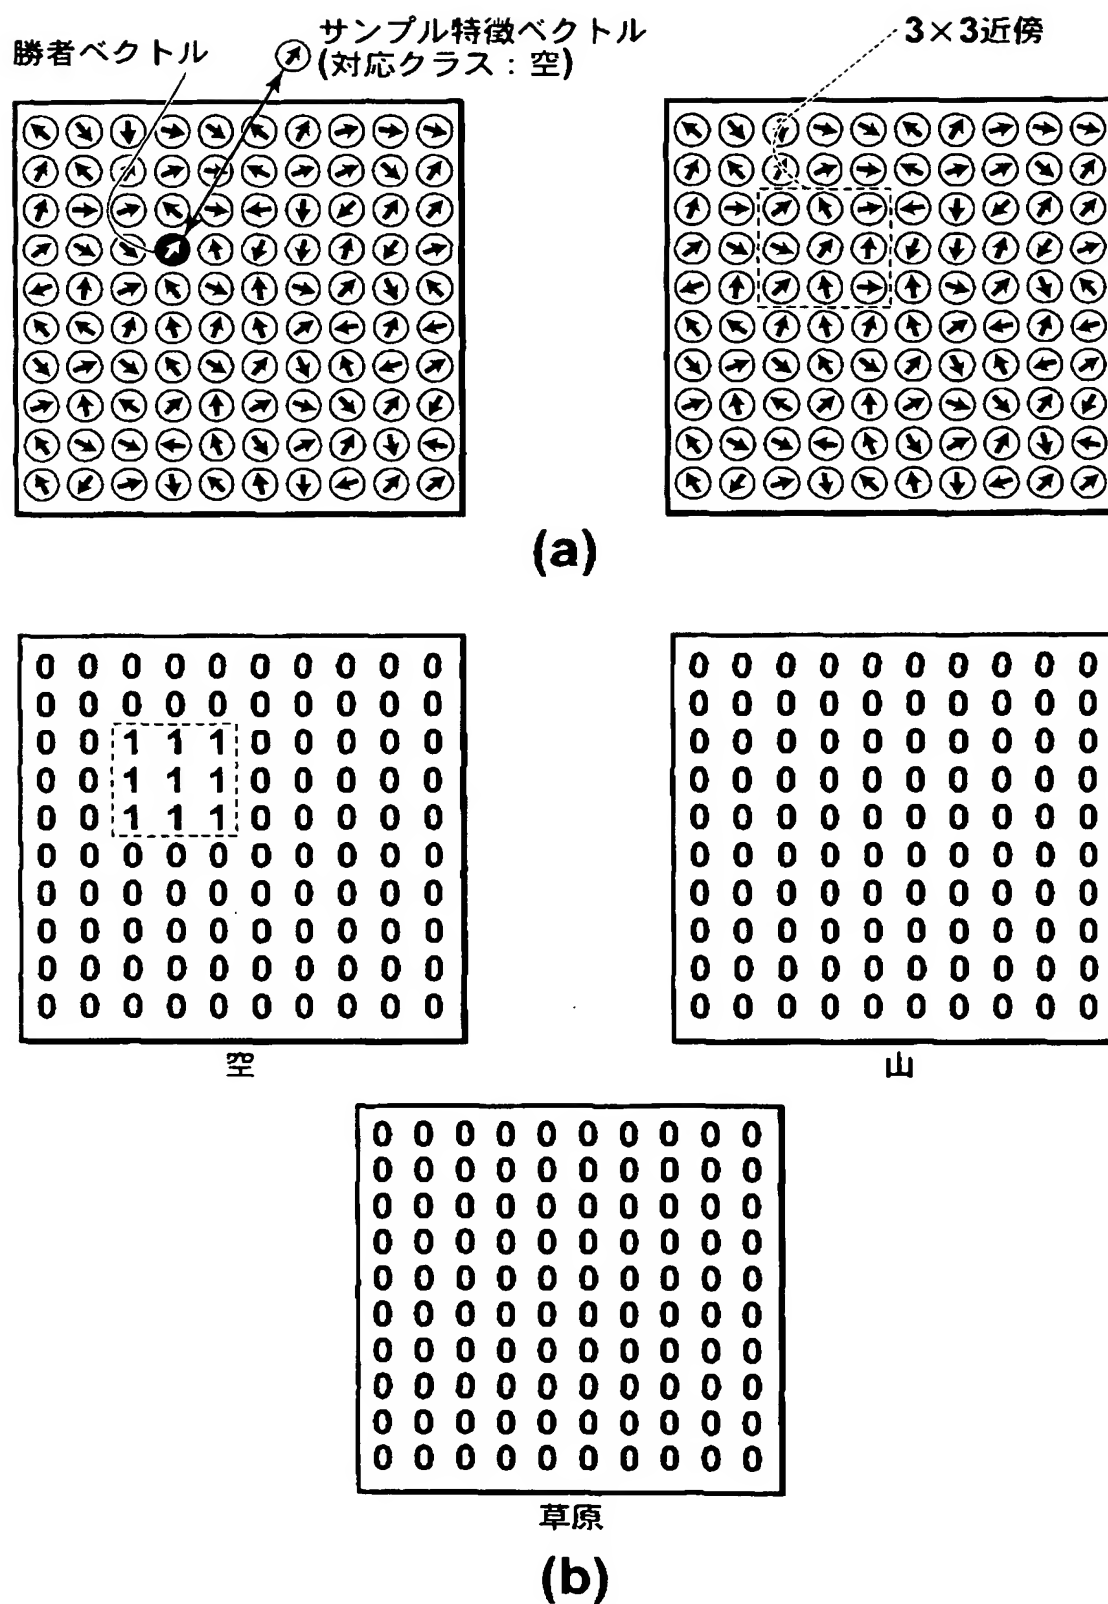
-1	0	1
-1	0	1
-1	0	1

(a) 縦エッジ検出用フィルター



-1	-1	-1
0	0	0
1	1	1

(b) 横エッジ検出用フィルター

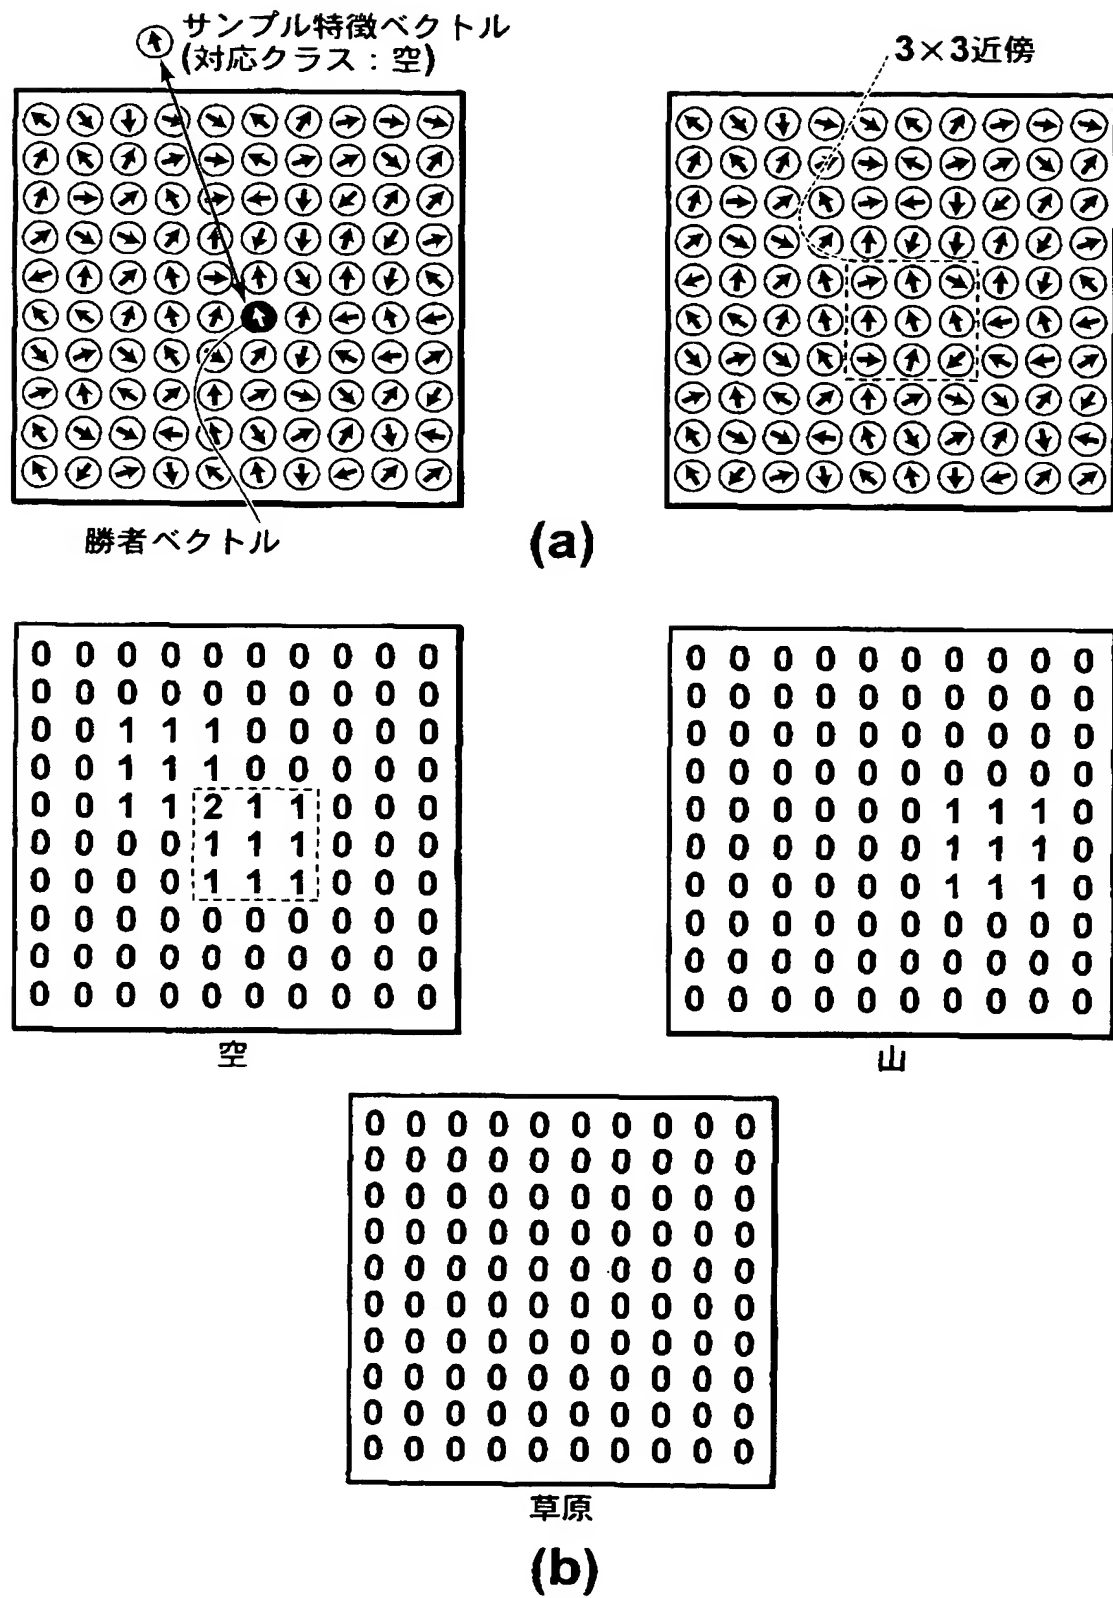
【図 4】



【図 5】





【図 6】




【図 7】

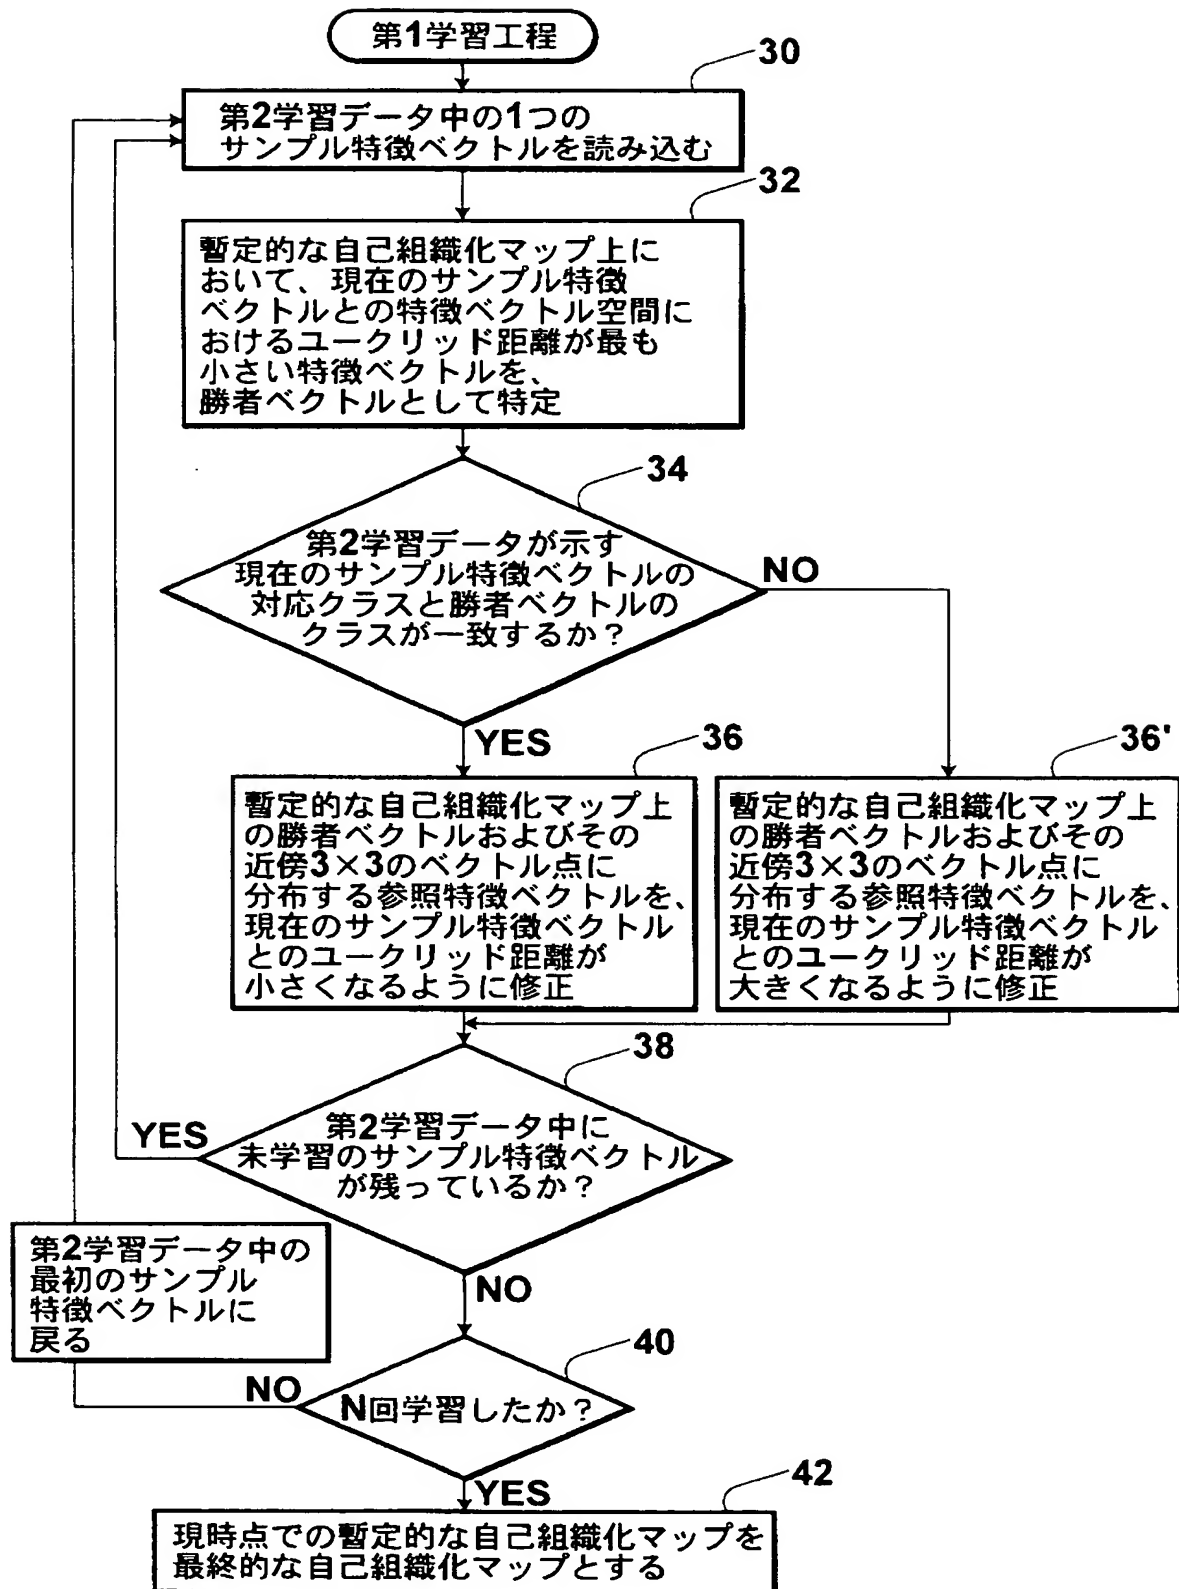
(a)



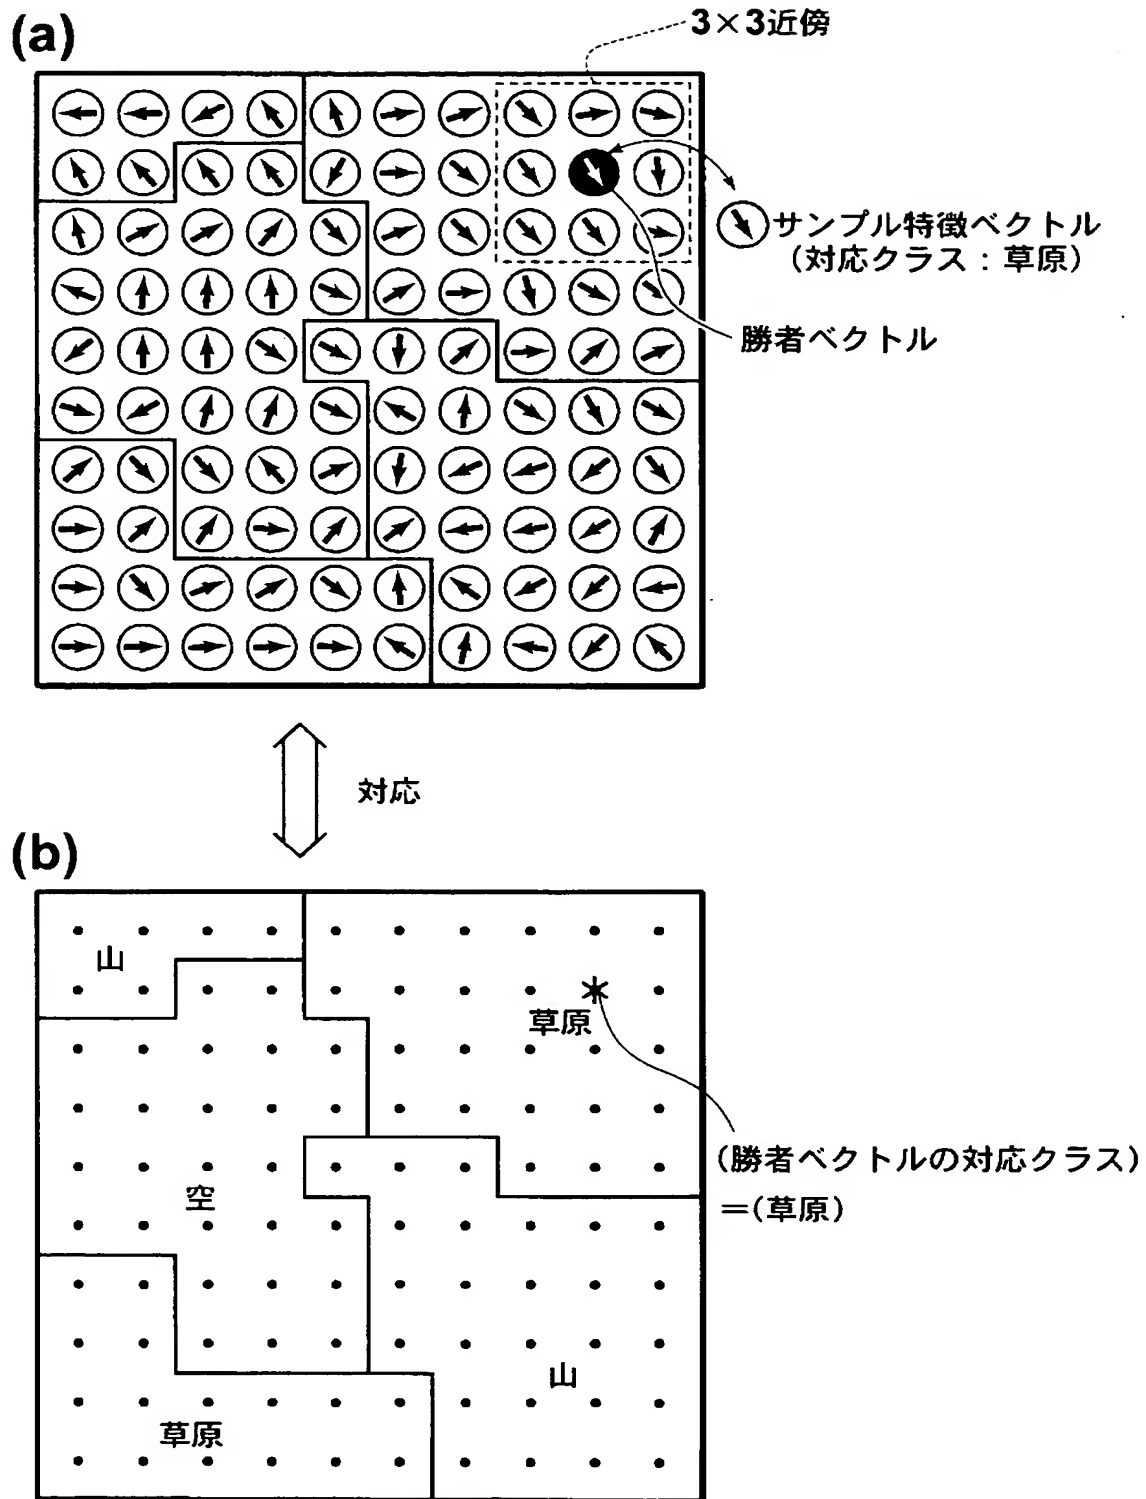
(b)



【図 8】





【図 9】

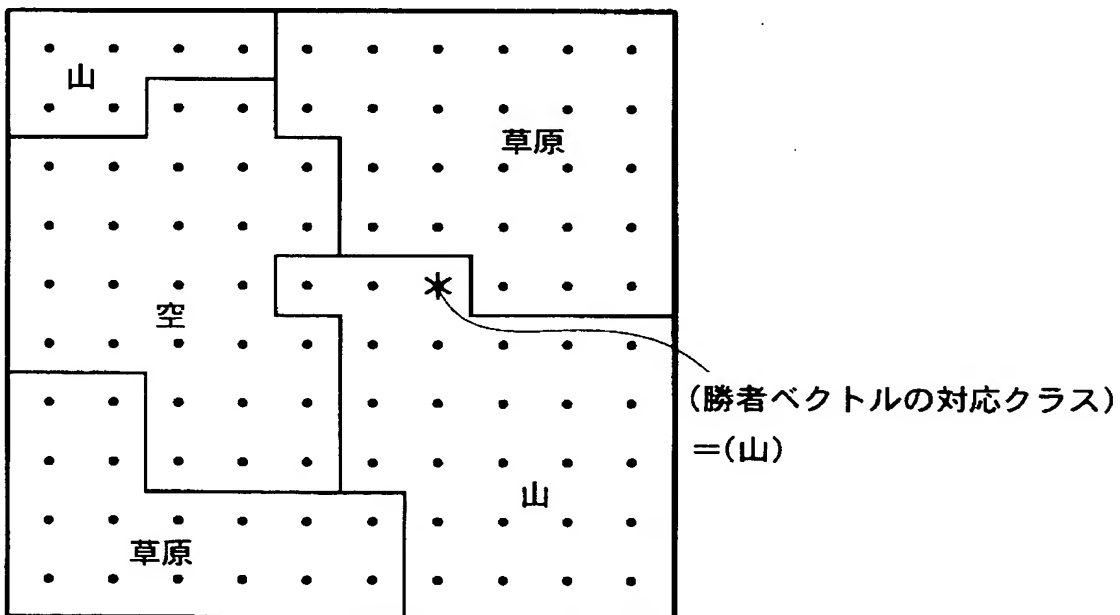


【図 10】


(a)



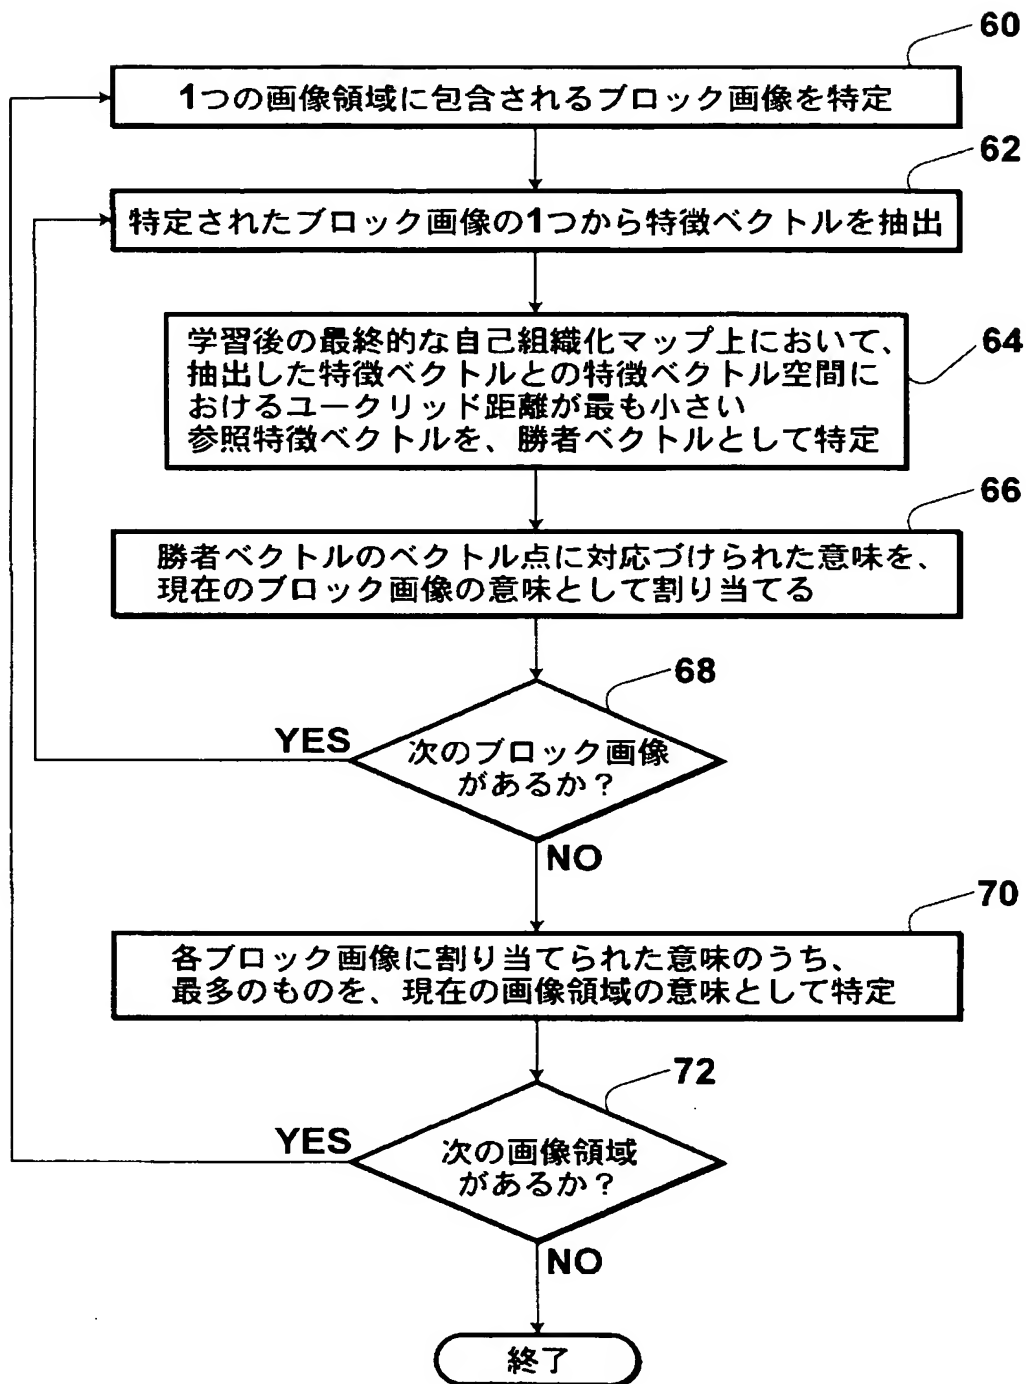
(b)



【図 11】




【図 12】



【図 13】

修正対向伝搬ネットワークによる
学習後の自己組織化マップ



【書類名】 要約書

【課題】 自己組織化マップによるデータ学習において、より高い精度で情報の内容判定処理を行うことができる自己組織化マップの導出を実現し、さらに、そのような学習後の自己組織化マップを用いて、より高い精度で、画像の意味判定処理を行うことを可能とする。

【解決手段】 第 1 学習工程または手段により各ベクトル点にクラスが対応付けられた暫定的な自己組織化マップを一旦導出した後、第 2 学習工程または手段により、学習ベクトル量子化に近傍学習の概念を取り入れた改良手法を用いて、暫定的な自己組織化マップに修正を加えていき、最終的な自己組織化マップを求める。また、そのように導出された最終的な自己組織化マップを用いて、画像の意味判定処理を行う。

【選択図】 図 8

認定・付加情報

特許出願の番号 特願 2 0 0 3 - 0 7 9 5 7 4
受付番号 5 0 3 0 0 4 6 7 0 7 3
書類名 特許願
担当官 第一担当上席 0 0 9 0
作成日 平成 1 5 年 4 月 1 日

< 認定情報・付加情報 >

【提出日】 平成15年 3月24日
【特許出願人】
【識別番号】 000005201
【住所又は居所】 神奈川県南足柄市中沼 2 1 0 番地
【氏名又は名称】 富士写真フイルム株式会社
【代理人】 申請人
【識別番号】 100073184
【住所又は居所】 神奈川県横浜市港北区新横浜 3 - 1 8 - 3 新横
浜 K S ビル 7 階
【氏名又は名称】 柳田 征史
【選任した代理人】
【識別番号】 100090468
【住所又は居所】 神奈川県横浜市港北区新横浜 3 - 1 8 - 3 新横
浜 K S ビル 7 階
【氏名又は名称】 佐久間 剛

次頁無

特願 2 0 0 3 - 0 7 9 5 7 4

出 願 人 履 歴 情 報

識別番号

[0 0 0 0 0 5 2 0 1]

1. 変更年月日

1 9 9 0 年 8 月 1 4 日

[変更理由]

新規登録

住 所

神奈川県南足柄市中沼 2 1 0 番地

氏 名

富士写真フイルム株式会社